

Sveučilište u Zagrebu
Prirodoslovno-matematički fakultet
Geografski odsjek

Matija Habijanec

PRIMJENA LANDSAT SNIMAKA U PRAĆENJU PROMJENA OKOLIŠA

Prvostupnički rad

Mentor: izv. prof. dr. sc. Aleksandar Toskić, (neposredni voditelj: dr. sc. Luka Valožić)

Ocjena:

Zagreb, 2017.

Sveučilište u Zagrebu
Prirodoslovno-matematički fakultet
Geografski odsjek

Prvostupnički rad

Primjena Landsat snimaka u praćenju promjena okoliša

Matija Habijanec, JMBAG: 0119029965

Preddiplomski sveučilišni studij *Geografija*; smjer: *istraživački*

Izvadak: U ovom radu razmatra se praćenje promjena okoliša pomoću Landsat Satelita na primjeru prostora oko Kaštelanskog zaljeva u Hrvatskoj. Prvo se objašnjavaju osnove daljinskih istraživanja te specifikacije Landsat satelita, a zatim se kreće se sa analizom promjena NDVI indeksa na navedenom prostoru primjenom ArcGIS softvera. Analiziraju se promjene unutar četiri razdoblja između 1972. i 2011. godine pomoću apsolutnih i relativnih pokazatelja. Zatim se pokušavaju protumačiti određene promjene u prostoru te njihova povezanost sa promjenom broja stanovnika, izgradnjom određenih objekata te sa prirodnim čimbenicima koji utječu na promjene NDVI vrijednosti. Na kraju se objašnjava problematika analize NDVI vrijednosti na krškom području te se razmatraju moguća rješenja za tumačenja pojedinih promjena.

30 stranica, 11 grafičkih priloga, 5 tablica, 12 bibliografskih referenci; izvornik na hrvatskom jeziku

Ključne riječi: Landsat, Kaštelanski zaljev, vegetacija, promjena okoliša, NDVI

Voditelj: izv. prof. dr. sc. Aleksandar Toskić, (neposredni voditelj: dr. sc. Luka Valožić)

Tema prihvaćena: 9. 5. 2017.

Datum obrane: 22. 9. 2017.

Rad je pohranjen u Središnjoj geografskoj knjižnici Prirodoslovno-matematičkog fakulteta Sveučilišta u Zagrebu, Marulićev trg 19, Zagreb, Hrvatska.

BASIC DOCUMENTATION CARD

University of Zagreb
Faculty of Science
Department of Geography

Bachelor Thesis

Application of Landsat imagery at observing environmental changes

Matija Habijanec, JMBAG: 0119029965

Undergraduate University Study of *Geography: course: research*

Abstract: This paper discusses the use of the Landsat satellites for observing the changes of the environment around the Kaštela bay in Croatia. Firstly, the basics of the remote sensing and specifications of Landsat satellites are presented, and then the objective moves to analysing the changes of NDVI values by using ArcGIS software. Analysis is done by observing the absolute and relative changes of NDVI values at four time periods between 1972. and 2011. Then, specific NDVI changes over time are explained and correlated with changes of population, building of certain objects and natural factors. Finally, the problems of NDVI analysis at karst areas is explained and possible solutions for explaining certain changes of NDVI values are discussed.

30 pages; 11 figures; 5 tables; 12 references; original in Croatian

Keywords: Landsat, Kaštela bay, vegetation, changes of environment, NDVI

Supervisor: Aleksandar Toskić, PhD, Associate Professor, (Luka Valožić, PhD)

Thesis submitted: 9. 5. 2017.

Thesis defense: 22. 9. 2017.

Thesis deposited in Central Geographic Library, Faculty of Science, University of Zagreb, Marulićev trg 19, Zagreb, Croatia.

SADRŽAJ

1. UVOD	1
2. OSNOVE DALJINSKIH ISTRAŽIVANJA	1
3. SPECIFIKACIJE LANDSAT SATELITA.....	4
4. PRIMJERI DOSADAŠNJIH ISTRAŽIVANJA	7
5. ANALIZA PROMJENE VEGETACIJSKIH INDEKSA PROSTORA KAŠTELANSKOG ZALJEVA U RAZDOBLJU 1976. – 2011.	8
6. ZALJUČAK.....	26
LITERATURA	27
IZVORI PODATAKA.....	29

1. UVOD

Jedan od glavnih ciljeva geografije kao znanosti je praćenje promjena intenziteta, rasprostranjenosti i odnosa pojava u prostoru. Daljinska istraživanja su glavna metoda prikupljanja takvih podataka koji se onda mogu dijakronijski analizirati. Ona se mogu definirati kao postupak prikupljanja podataka o nekom prostoru pomoću uređaja koji nije u izravnom kontaktu s tim prostorom (Lillesand i dr., 2004)

Prve zračne snimke pojavljuju se još u 19. stoljeću, a važnost zračnih snimaka se povećava tijekom Prvog i Drugog svjetskog rata. Međutim, pojam „daljinska istraživanja“ pojavljuje se tek u drugoj polovici 20. stoljeća pojavom prvih satelita namijenjenih za snimanje Zemljine površine (Campbell i Wayne, 2011). Pojava Landsat satelita je važna za daljinska istraživanja jer označava početak kontinuiranog praćenja Zemljine površine od 1972. godine. To je od velike važnosti za geografiju jer omogućava analiziranje promjena okoliša te će se upravo na toj činjenici temeljiti i ovaj rad.

U ovom radu koristiti će se metoda deskripcije i analize literature, te GIS analize u ArcGIS softveru. Cilj ovog rada je utvrditi mogućnosti analiza prostora pomoću slika snimljenih Landsat satelitima, njihove doprinose u razumijevanju prostornih procesa te provesti vlastitu analizu prostora Kaštelanskog zaljeva.

2. OSNOVE DALJINSKIH ISTRAŽIVANJA

U ovom radu proučavati će se daljinska istraživanja provedena isključivo iz satelita. Ostale vrste uključuju i daljinska istraživanja iz drugih letećih platformi ili sa Zemljine površine, no u ovom radu će se termin „daljinska istraživanja“ odnositi ponajprije na satelitske snimke.

Kako bi se što bolje interpretirala snimka nekog prostora, potrebno je znanje o sustavu koji vrši daljinska istraživanja, znanje o predmetu istraživanja te razumijevanje geografskog prostora koji se na snimci istražuje (Campbell i Wayne, 2011).

Kvaliteta svakog satelitskog snimka određena je njegovim rezolucijama. Četiri osnovna tipa rezolucija u daljinskim istraživanjima su prostorna, spektralna, vremenska i radiometrijska. Prostorna rezolucija odnosi se na veličinu piksela dok se prostorni obuhvat

odnosi na dimenzije snimke. Spektralna rezolucija odnosi se na broj spektralnih kanala te njihov obuhvat. Manja razlika između najveće i najmanje vrijednosti obuhvaćenih valnih duljina kod nekog spektralnog kanala dovodi do bolje spektralne rezolucije. Vremenska rezolucija temelji se na vremenskom razmaku potrebnom da satelit snimi isto područje, a radiometrijska rezolucija odnosi se na detaljnost u detekciji jačine elektromagnetskog zračenja te se mjeri u bitovima (Campbell i Wayne, 2011).

Kako bi se mogle provesti analize nekog prostora, potrebno je uskladiti podatke, a to se ponajprije odnosi na geometrijske i atmosferske korekcije, georeferenciranje, prilagođavanje rezolucije piksela te njihovo usklađivanje. Geometrijske korekcije su potrebne zbog manjih varijacija u orbiti satelita što dovodi to nepravilnosti u geometriji snimke. Ipak, značajniji problem kod svih daljinskih istraživanja temeljenih na teledetekciji predstavlja Zemljina atmosfera koja modificira elektromagnetske valove koji dolaze sa zemljine površine do satelita, što smanjuje točnost prikupljenih podataka, a navedene modifikacije su najizraženije kod manjih valnih duljina pa će im plava boja biti najviše podložna. Njihovo uklanjanje je kompleksan proces koji se temelji na modeliranju efekata apsorpcije i raspršenja elektromagnetskih valova u atmosferi, a povezano je s vremenskim uvjetima prisutnima u vrijeme izrade snimke, poput primjerice količine vodene pare u atmosferi (Richards i Jia, 2006).


Dodjeljivanjem crvene, zelene i plave boje različitim spektralnim kanalima dobiva se kompozitna slika koja može prikazivati te boje u prostoru onako kako ih vidi ljudsko oko (tzv. *true color*, sl. 1. i 2.), ali ih može prikazivati i u drugim kombinacijama (tzv. *false color*, Sl. 8.), pogotovo kada se koriste spektralni kanali valnih duljina izvan vidljivog djela elektromagnetskog spektra gdje je glavni cilj uočavanje određenih pojava u prostoru, a ne vjerodostojnost stvarnih boja. Kombinacija spektralnih kanala se najčešće određuje njihovim redanjem u smjeru crvena, zelena, plava pa tako 321 kombinacija označava dodjeljivanje crvene boje trećem, zelene drugom, a plave prvom kanalu.

Ako su snimke različitih prostornih rezolucija, potrebno je rezoluciju jedne snimke prilagoditi drugoj. Piksela manje rezolucije je većih dimenzija te se on može smanjiti (primjerice alatom *resample* u ArcGIS-u), a ono se može temeljiti na više metoda. Najčešće su metode najbližeg susjeda, bilinearna interpolacija te kubična konvolucija. Metoda najbližeg susjeda će novom pikselu dodijeliti vrijednost najbliže susjedne točke što znači da će se stare vrijednosti zadržati, ali će doći do greške jer se neće u obzir uzeti vrijednost

ostalnih piksela koji su se nalazili u blizini. S druge strane, metoda bilinearne interpolacije će u obzir uzeti vrijednosti četiri najbliža susjeda te izračunati njihov težinski prosjek temeljen na udaljenosti, a to pak znači gubitak originalnih vrijednosti, no precizniju vrijednost novih piksela. Metoda kubične konvolucije će pak u obzir uzeti 16 susjednih piksela (Campbell i Wayne, 2011).

Zbog toga što svaki piksel određuje jednaku vrijednost bilo koje točke koja se nalazi na njemu, u slučaju bilinearne interpolacije i kubične konvolucije, povećavanje rezolucije snimka neće znatno doprinijeti točnosti podataka, dok će u slučaju metode najbližeg susjeda, vrijednosti ostati potpuno iste pa će novonastali raster izgledati identično kao i prije, samo će mu se broj piksela povećati. Stoga, kako bi se zadržala točnost podataka, snimke veće rezolucije moraju se prilagoditi onima manje rezolucije, a metodama bilinearne interpolacije i kubične konvolucije novonastali veći pikseli imati će precizne vrijednosti.

Ipak, rezolucija nekih snimaka se pak može povećati pomoću pankromatskih snimaka koje snimaju senzori na nekim satelitima poput primjerice Landsata 7 i 8. Pankromatska snimka obuhvaća valne duljine cijelog vidljivog djela spektra te je veće rezolucije od snimaka ostalih spektralnih kanala. Takve snimke se pomoću alata *Pan sharpening* u ArcGIS-u mogu koristiti za povećanje rezolucije RGB kompozitne snimke, u slučaju Landsat satelita, sa 30x30 metara na 15x15 metara. Na slici 1. se tako može puno bolje raspoznati stadion Poljud kada je povećana rezolucija pomoću pankromatske snimke.



Sl. 1. Satelitska snimka zapadnog djela Splita rezolucije 30x30 metara (lijevo) pretvoren u rezoluciju 15x15 metara pomoću pankromatske snimke 15. 7. 2005.

Izvor: GloVis

3. SPECIFIKACIJE LANDSAT SATELITA

Razumijevanje sustava koji vrši daljinska istraživanja jedan je od tri temelja uspješne interpretacije satelitskog snimka te je stoga cilj ovog poglavlja razmotriti karakteristike Landsat satelita.

Tablica 1. prikazuje rezolucije kod Landsat satelita. Vidljivo je kako je većina satelita opremljena s više senzora od kojih svaki ima zasebne spektralne kanale i rezolucije. Stoga je preciznije govoriti o rezolucijama određenog senzora (npr. MSS), nego o rezolucijama primjerice, Landsat 2 satelita.

Tab. 1. Karakteristike Landsat satelita

Satelit	Broj spektralnih kanala i senzori	Prostorna rezolucija	Dimenzije snimka	Vremenska rezolucija	Radiometrijska rezolucija	Vrijeme rada
Landsat 1	4(MSS), 3(RBV)	60x60, 80x80	170x185 km	18 dana	6 bita	1972. - 1978.
Landsat 2	4(MSS), 3(RBV)	60x60, 80x80	170x185 km	18 dana	6 bita	1975. - 1983.
Landsat 3	5(MSS), 3(RBV)	60x60, 40x40	170x185 km	18 dana	6 bita	1978. - 1983.
Landsat 4	4(MSS), 7(TM)	60x60, 30x30	170x185 km	16 dana	8 bita	1982. - 1993.
Landsat 5	4(MSS), 7(TM)	60x60, 30x30	170x185 km	16 dana	8 bita	1984. - 2013.
Landsat 7	8(ETM+)	30x30 (15x15*)	170x185 km	16 dana	8 bita	1999. -
Landsat 8	9(OLI), 2(TIRS)	30x30 (15x15*)	170x185 km	16 dana	12 bita	2013. -

Izvor: USGSa

Kod prva tri Landsat satelita najvažniji je bio MSS senzor koji je imao 4 spektralna kanala; 2 u infracrvenom te 2 u vidljivom djelu elektromagnetskog spektra (USGSb). Samo dva kanala u vidljivom djelu spektra ne omogućavaju izradu *true color* kompozitnih slika s obzirom na to da se plava boja nije detektirala senzorom, a razlog toga je vjerojatno već spomenuti negativan utjecaj atmosfere na kratke valne duljine .

Landsat 4 i 5 sateliti koristili su i TM senzor koji je imao iste dimenzije snimka kao MSS, no bolju prostornu rezoluciju (30x30) te veći broj spektralnih kanala (7), što znači da je omogućavao veći broj mogućih analiza te povećao njihovu preciznost (USGSa).

Landsat 7 koristi ETM+ senzor koji, osim svih spektralnih kanala TM senzora, posjeduje i pankromatski kanal (označeno zvjezdicom), dok Landsat 8 OLI/TIRS senzori posjeduju još dodatna 3 spektralna kanala. Pojedini spektralni kanali imaju posebnu namjenu, pa je tako primjerice kanal 9 OLI senzora namijenjen isključivo za detekciju *cirrus*

oblaka (USGSb). Vidljivo je kako se raspon valnih duljina unutar pojedinog spektralnog kanala smanjuje s uvođenjem novijih satelita i boljih senzora (Tab. 2.), a to omogućava analize posebnih pojava koje zrače u specifičnim valnim duljinama.

Također valja napomenuti kako Landsat 7 ima problema sa ETM+ senzorom te kod svake snimke gubi preko 20 % podataka (vidljivo na slici 2.) što uzrokuje nepouzdanost kod prostornih analiza (USGSc). Landsat 7 i 8 sateliti svaki dan zajedno naprave oko 1100 snimaka (USGSd), a njihove orbite su sinkronizirane na način da uvijek snimaju po danu te razlika između njihovih orbita iznosi 8 dana, što dovodi do jednakog intervala između snimaka, te u sklopu zajedničkog sustava ta dva satelita vremenska rezolucija iznosi samo 8 dana (USGSe).

Dakle, od prvog do najnovijeg Landsat satelita došlo je do brojnih unaprjeđenja, prije svega u broju spektralnih kanala i prostornoj rezoluciji, ali su zadržane osnovne karakteristike poput prostornog obuhvata te je uspostavljen kontinuitet neprekinutog praćenja prostora što olakšava njihovo međusobno uspoređivanje.

Tab. 2. Specifikacije spektralnih kanala različitih senzora Landsat satelita

MSS		
Spektralni kanal	Valna duljina (μm)	Prostorna rezolucija (m)
1	0,5 - 0,6	79x57 (60x60)
2	0,6 - 0,7	79x57 (60x60)
3	0,7 - 0,8	79x57 (60x60)
4	0,8 - 1,1	79x57 (60x60)

OLI/TIRS		
Spektralni kanal	Valna duljina (μm)	Prostorna rezolucija (m)
1	0,435 - 0,451	30x30
2	0,452 - 0,512	30x30
3	0,533 - 0,590	30x30
4	0,636 - 0,673	30x30
5	0,851 - 0,879	30x30
6	1,566 - 1,651	30x30
7	2,107 - 2,294	30x30
8	0,503 - 0,676	15x15
9	1,363 - 1,384	30x30
10	10,60 - 11,19	100x100 (30x30)
11	11,50 - 12,51	100x100 (30x30)

TM		
Spektralni kanal	Valna duljina (μm)	Prostorna rezolucija (m)
1	0,45 - 0,52	30x30
2	0,52 - 0,60	30x30
3	0,63 - 0,69	30x30
4	0,76 - 0,90	30x30
5	1,55 - 1,75	30x30
6	10,40 - 12,50	120x120 (30x30)
7	2,08 - 2,35	30x30

ETM+		
Spektralni kanal	Valna duljina (μm)	Prostorna rezolucija (m)
1	0,45 - 0,52	30x30
2	0,52 - 0,60	30x30
3	0,63 - 0,69	30x30
4	0,77 - 0,90	30x30
5	1,55 - 1,75	30x30
6	10,40 - 12,50	60x60 (30x30)
7	2,09 - 2,35	30x30
8	0,52 - 0 - 90	15x15

Landsat 1, 2 i 3 sateliti nalazili su se na visini od oko 900 kilometara, a ostali Landsat sateliti su na visini od 700 kilometara (USGSa). S obzirom na to da debljina Zemljine atmosfere iznosi oko 100 kilometara (NASA), elektromagnetski valovi na svojem putu sa Zemljine površine do satelita zbog toga prolaze kroz cijelu Zemljinu atmosferu gdje su podložni brojnim modifikacijama. Snimke sa zrakoplova će biti manje podložne spomenutim modifikacijama jer se zbog manje visine smanjuje debljina atmosfere između senzora i prostora koji se proučava.

Satelitske snimke veće prostorne rezolucije omogućavaju preciznije analize prostora, no prostorni obuhvat takvih snimaka je često vrlo mali u usporedbi sa snimkama nižih rezolucija. Primjerice, pankromatski snimak Worldview 4 satelita ima prostornu rezoluciju od 30 centimetara te taj satelit može dnevno snimiti 680 000 km² površine (DigitalGlobe). Landsat 8 ima rezoluciju pankromatskog snimka od 15 metara, a dnevno može snimiti 24 000 000 km² površine (USGSd). MODIS senzor na satelitima Terra i Aqua snimi cijelu Zemlju u razdoblju od 1 do 2 dana u 36 spektralnih kanala, no rezolucija tih snimaka iznosi od 250 do 1000 metara (NASAb). Zbog toga se sateliti vrlo visokih rezolucija koriste za analize ciljanih područja radi znanstvenih ili komercijalnih svrha gdje je visoka rezolucija od velike važnosti, no zbog ograničenog prostornog obuhvata nisu pogodni za promatranje globalnih procesa. S druge strane, niže rezolucije poput spomenutog MODIS senzora ograničavaju mogućnost uočavanja brojnih geografskih značajki prostora. Senzori na Landsat satelitima imaju ravnotežu između prostornog obuhvata, te prostorne i vremenske rezolucije koja je najpogodnija za geografska istraživanja, a osim navedenog, glavne prednosti Landsat snimaka su i dugi kontinuitet praćenja Zemlje u cijelosti te besplatna dostupnost snimaka na internetu.

Prostorna rezolucija Landsat satelita je dovoljno velika za praćenje antropogenih utjecaja na zemljišni pokrov, a dimenzije snimka su dovoljno velike za analize većih prostora (Wulder i dr., 2012). Osim procesa suvremenih antropogenih utjecaja poput praćenja poljoprivrednih usjeva, deforestacije, suburbanizacije ili upravljanja riječnim tokovima, mogu se pratiti i procesi prirodne osnove poput erupcija vulkana, poplava, ili kretanja ledenjaka. Svi ti procesi su ujedno i glavna tema mnogih istraživanja u geografiji pa zbog toga Landsat snimke čine osnovu brojnih prostornih analiza.

Landsat program će se nastaviti i u budućnosti te bi se predviđen Landsat 9 sa unaprijeđenim senzorima trebao lansirati u Zemljinu orbitu 2020. godine (NASAc). Posljednjih godina uspostavljen je sustav Sentinel 2 satelita od strane Europske svemirske agencije koji se odlikuje boljom rezolucijom i većim brojem spektralnih kanala od Landsat 8 satelita (ESA), te može služiti kao zaseban ili dodatan besplatan izvor za novija daljinska istraživanja. Zbog sličnosti u rasponima valnih duljina kod spektralnih kanala između Sentinel i Landsat satelita, njihovi podaci se mogu međusobno uspoređivati i nadopunjavati.

4. PRIMJERI DOSADAŠNJIH ISTRAŽIVANJA

Do naglog porasta korištenja Landsat snimaka dolazi 2008. godine kada su snimke postale besplatne što je omogućilo dostupnost širem broju istraživača (Wulder i dr., 2012). Stoga, iako je prvi Landsat satelit počeo snimati Zemljinu površinu 1972. godine, ti su snimci imali ograničenu dostupnost, pa do pojave brojnih radova koji se koriste Landsat snimcima dolazi znatno kasnije. Jedan od najstarijih radova vezan za analizu podataka Landsat satelita proučava promjene spektralnih karakteristika poljoprivrednih usjeva tijekom vremena. Tako je primjerice, ustanovljen odnos između infracrvenog i crvenog zračenja tijekom faza razvoja pšenice. Dakle, analizom spektralnih svojstva Landsat snimke može se primjerice utvrditi radi li se o tek posijanoj pšenici ili je pak vrijeme za žetvu (Kauth i Thomas, 1976). Drugi primjer ranijih korištenja Landsat snimaka je klasifikacija i utvrđivanje potencijalnih arheoloških nalazišta u Delawerau (Custer i dr., 1986).

Osim vegetacije, moguće je analizirati i spektralne karakteristike drugih pojava, poput primjerice snijega. Tako je moguće utvrditi prosječnu veličinu zrna snijega na temelju reflektiranog infracrvenog zračenja, ali i razlikovati snijeg od oblaka (Dozier, 1989). Osim cijene i dostupnosti Landsat snimaka, jedan od glavnih problema ranijih analiza Landsat snimaka, ali i svih rasterskih podataka bila je spora obrada zbog računala toga doba, te su takve zadatke u to doba mogla obavljati samo teže dostupna superračunala.

Gotovo svaka analiza Landsat snimaka završava klasifikacijom zemljine površine s obzirom na karakteristike određenih područja. Moguće je provesti vrlo točne klasifikacije zemljišta te analizirati njihove promjene tijekom vremena, primjerice u Minnesoti (Yuan i dr., 2005). U tom radu izrađene su matrice promjene korištenja zemljišta, te se traži pozitivna

korelacija između širenja urbanih područja povećanja broja stanovnika. Primjer korištenja snimaka najnovijeg Landsat 8 satelita u Hrvatskoj dobro se očituje u analizi šteta u šumama prouzročenih ledenom kišom 2014. godine u Gorskom kotaru (Šimić Milas i dr., 2015). U tom radu su klasificirana najugroženija šumska područja pomoću promjene vrijednosti vegetacijskog indeksa, a slična metoda koristiti će se i u ovom radu.

5. ANALIZA PROMJENE VEGETACIJSKIH INDEKSA PROSTORA KAŠTELANSKOG ZALJEVA U RAZDOBLJU 1976. – 2011.

Razumijevanje predmeta istraživanja drugi je temelj uspješne interpretacije satelitske snimke pa će se ovdje razmotriti istraživanje vegetacijskog pokrova koji se najčešće proučava pomoću vegetacijskih indeksa.

Vegetacijski indeksi su pokazatelji biomase ili koncentracije vegetacije, a najčešće su bazirani na omjeru između dva spektralna kanala. Osnovni princip na kojem se temelje vegetacijski indeksi je činjenica da zelene biljke apsorbiraju crvenu boju dok klorofil u njima emitira infracrveno zračenje. Kada primjerice na jesen listovi postaju suhi, povećava se reflektirano crveno zračenje (pa ih naše oči percipiraju kao crvene), a smanjuje se reflektirano infracrveno zračenje (nestaje klorofil) pa se vegetacijski indeks smanjuje. Dakle, povećavanjem razlike između reflektiranog crvenog i infracrvenog elektromagnetskog zračenja povećava se vjerojatnost da se radi o zelenoj biljki. Međutim, vegetacijske indeksi su, kao i ostali podaci prikupljeni daljinskim istraživanjima, podložni modifikacijama zbog atmosferskih efekta koji degradiraju kvalitetu snimke (Campbell i Wayne, 2011).

Nedugo nakon prvog Landsat satelita počinju se pojavljivati znanstveni radovi koji pokušavaju protumačiti određene prostorne značajke kao odraz kvantitativnih karakteristika spektralnih kanala. Jedan od najuspješnijih takvih primjera u slučaju vegetacije je NDVI (*Normalized difference vegetation index*) indeks koji se temelji na omjeru između infracrvenog i crvenog spektralnog kanala (Rouse i dr., 1973 prema Tucker, 1978). Formula za NDVI indeks je: $(\text{Infracrveni kanal} - \text{crveni kanal}) / (\text{infracrveni kanal} + \text{crveni kanal})$.

Vegetacijske indekse koriste brojni autori te oni predstavljaju provjerenu i uvaženu metodu analize. Očekuje se kako će područja s većim vegetacijskim indeksima prikazivati

nenaseljene prostore dok će niži vegetacijski indeksi prikazivati ponajprije urbana područja Splita i okolice.

Konačno, potrebno je razumjeti i prostor koji se proučava, a to je u ovom slučaju Kaštelanski zaljev, područje između Splita i poluotoka Čiovo, a to je zapravo najpovoljnije područje za širenje splitske gradske regije. To područje je prikazano tamnijom bojom na slici 2., a tamne linije desno od tog područja posljedica su već spomenutog problema s ETM+ senzorom. Pretpostavlja se kako je u tom prostoru došlo do izražene suburbanizacije u posljednjih 40 godina. To je područje mediteranske klime i krškog reljefa gdje se uz urbana područja nalaze prostori pokriveni makijom, područja golog krša Kozjaka i Mosora te manja izdvojena šumska područja. Površina mora se neće analizirati.



Sl. 2. Kompozitna (321 RGB) satelitska snimka područja šire okolice Splita, promatrano područje označeno je tamnijom bojom, 15. 7. 2005.

Izvor: GloVis

Navedeno područje obuhvaća prostor grada Solina i Kaštela te dijelove grada Splita, Trogira i općina Dugopolje, Klis, Lećevica, Prgomet, Seget i Okrug. Područje je definirano prema teritorijalnim jedinicama 34 naselja koja se nalaze uz Kaštelanski zaljev te obuhvaćaju prostor do oko 10 kilometara u unutrašnjost. To je područje površine 366 km² te će se na njemu analizirati usporedbe na temelju vrijednosti vegetacijskih indeksa zabilježenih 1972., 1990., 2000., 2005. i 2011. godine. Odabrane snimke snimljene su tijekom ljetnih mjeseci MSS, TM i ETM+ senzorima na Landsat satelitima prostorne rezolucije 60 (MSS) i 30 (TM i ETM+) metara. Snimke su preuzete sa stranica GLS (*Global Land Survey*) te su već georeferencirane i na njima su već izvršene atmosferske i ostale korekcije.

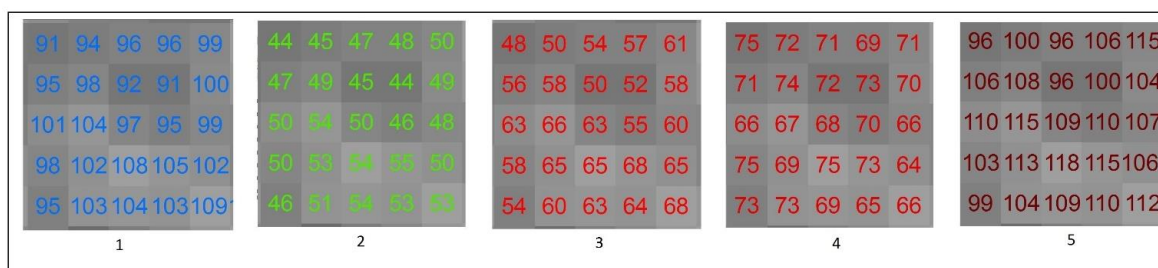
S obzirom na to da je rezolucija MSS senzora manja od ostalih snimaka, potrebno joj je prilagoditi ostale snimke veće rezolucije. Ponovnim uzorkovanjem piksela snimke, metodom bilinearne interpolacije, smanjena je prostorna rezolucija ostalih snimaka s 30 na 60 metara po pikselu. Nakon toga je ustanovljeno da se pikseli novostvorenih rastera ne poklapaju s pikselima MSS senzora (što može dovesti do krivih rezultata analize) pa su izvršene dodatne prilagodbe kod kojih je mreža novostvorenih piksela služila kao okvir za piksele snimka iz 1972. godine nakon čega su oni ponovno uzorkovani i izrezani te su stvoreni novi slojevi koji se poklapaju.

U slučaju Landsat TM i ETM+ senzora crveni i infracrveni su kanali 3 i 4 dok je u slučaju MSS senzora (1972. godina) NDVI izračunat kao omjer crvenoga (2) i srednje vrijednosti između kanala 3 i 4. Razlog toga je razlika u rasponu valnih duljina infracrvenog kanala kod MSS senzora (kanal 3 u rasponu 0,7 – 0,8 μm te kanal 4 raspona 0,8 – 1,1 μm) koji se onda prilagođavaju valnoj duljini kanala 4 TM i ETM+ senzora (0,76 – 0,90 μm) tako da se izračunaju njihovi prosjeci te zatim aritmetička sredina tih prosjeka koja je slična onoj od TM i ETM+ senzora.

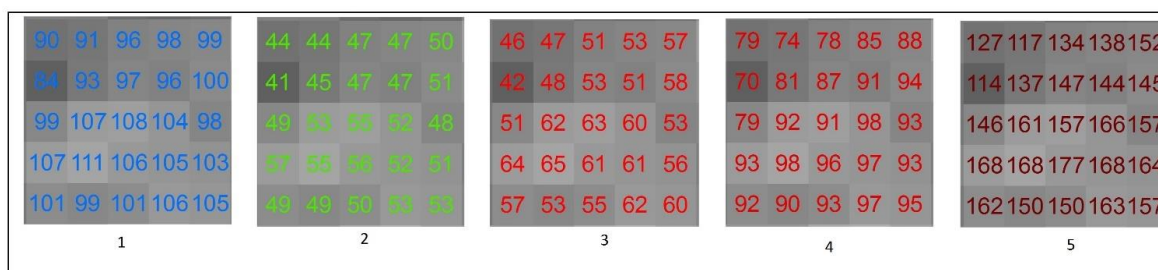
Nakon što je izračunat NDVI svakog rastera, oduzeti će se rasteri uzastopnih godina kako bi se dobila promjena NDVI indeksa koja je temelj za daljnju analizu. Neki autori (npr. Masek i dr., 2000) predlažu definiranje graničnih vrijednosti koje će definirati promjenu kako bi se izbacile nepouzidane vrijednosti blizu nule. Oni su u svojem radu koristili kombinaciju promjene NDVI-a te klastere dobivene ISODATA algoritmom za nenadziranu klasifikaciju.

U spomenutom radu analizira se područje okolice grada Washington DC gdje je značajna razlika u vrijednosti piksela između područja grada i okolnih šuma ili poljoprivrednih zemljišta. S druge strane, na području Kaštelanskog zaljeva slične vrijednosti piksela između gradskog područja i ogoljelog krša (Sl. 3 i 4.) otežavaju klasifikaciju zemljišta te stoga ta metoda u ovom slučaju nije dala zadovoljavajuće rezultate. Može se zaključiti kako uspješnost određene metodologije znatno ovisi o prirodnim karakteristikama područja koje se promatra.

Kako bi se detaljnije proučila problematika daljinskih istraživanja krškog područja, nasumično su odabrane mreže od 5x5 piksela oko centra Kaštel Sućurca te područja oko grebena obližnjeg Kozjaka iz 2011. godine. Nakon toga su analizirane vrijednosti piksela od 1,2,3,4 i 5 kanala TM senzora između ta dva područja (Sl. 3. i 4.). Zatim su izračunate aritmetičke sredine svih 25 piksela te su uspoređivane između istih spektralnih kanala. Vidljivo je kako se s povećanjem spektralnog kanala, a time i valne duljine povećavaju razlike između aritmetičkih sredina piksela navedenih područja (Tab. 3.).



Sl. 3. Vrijednosti piksela po spektralnim kanalima TM senzora kod područja oko centra Kaštel Sućurca 2011.



Sl. 4. Vrijednosti piksela po spektralnim kanalima TM senzora kod područja oko grebena Kozjaka

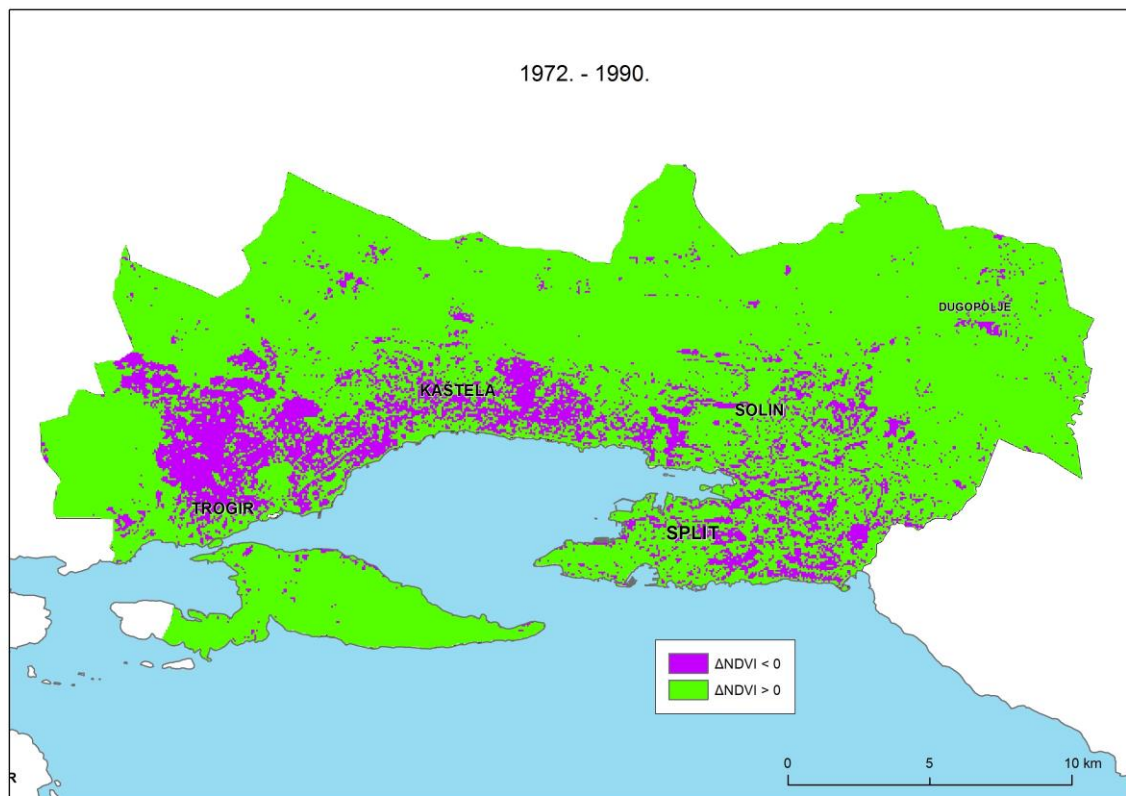
Tab. 3. Usporedba vrijednosti piksela sa slika 3. i 4.

Spektralni kanal (Landsat 5)	Razlika između aritmetičkih sredina vrijednosti piksela
1 (plava)	1,1
2 (zelena)	0,4
3 (crvena)	3,6
4 (infracrvena)	18,7
5 (infracrvena)	44,1

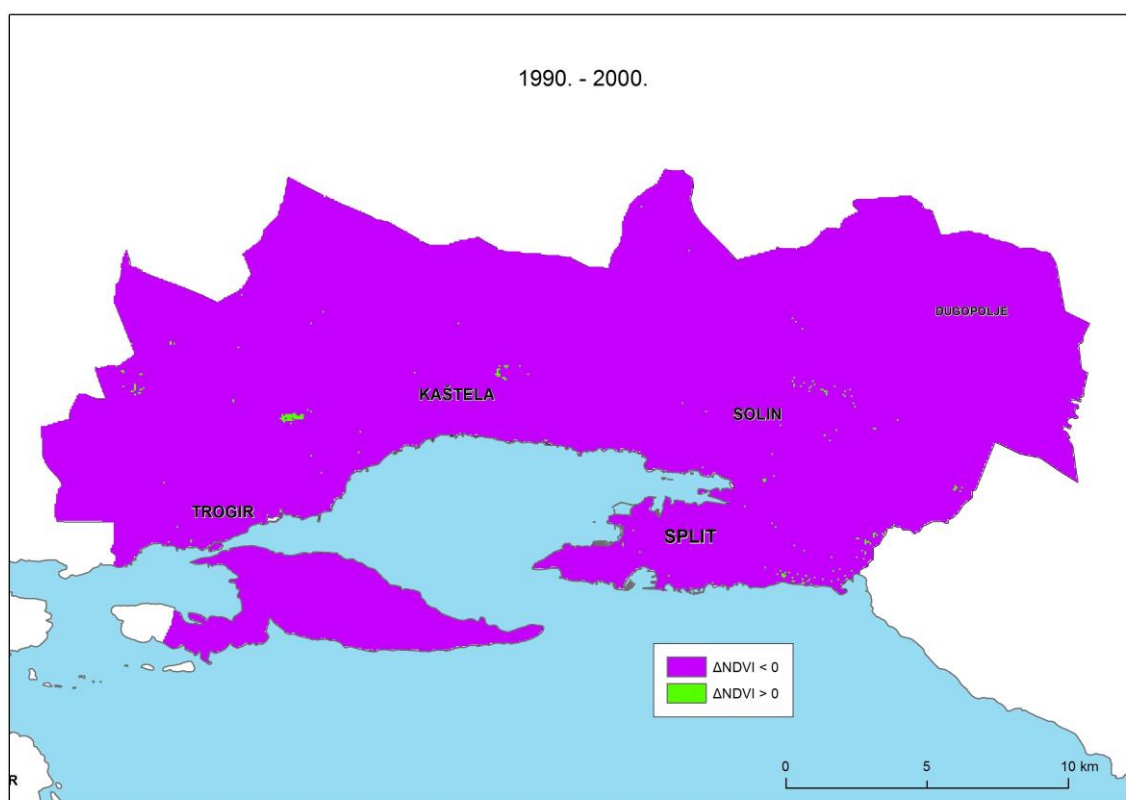
Sljedeći problem predstavljaju velike varijacije NDVI vrijednosti između različitih promatranih razdoblja. Primjerice, u razdoblju 1990. – 2000. (Sl. 5b) dolazi do smanjenja NDVI vrijednosti kod čak 99 % piksela dok u razdoblju 2005. – 2011. dolazi do smanjenja kod samo 0,3 % piksela (Sl. 5d). Pokušano je, kao u spomenutom radu, odrediti granične vrijednosti pa u slučaju kada svaka vrijednost promjene niža od -0,1 smatra negativnom, u razdoblju 2005. – 2011. ona će obuhvatiti samo 0,04 % svih piksela dok će u razdoblju 1990. – 2000. obuhvatiti preko 95 % piksela.

Naravno, te varijacije nisu posljedica antropogenog djelovanja niti ukazuju na fizičku transformaciju prostora, već se vjerojatno radi o općenitim promjenama intenziteta vegetacije zbog varijabilnosti vremenskih prilika između ljetnih mjeseci različitih godina. Bez obzira na to što se radi o snimcima iz 8. mjeseca, moguće su znatne varijacije u intenzitetu vegetacije između pojedinih godina. To se može objasniti činjenicom da je godina 2000. proglašena jednom od najtoplijih i najsušnijih u Hrvatskoj (NN 24/10), što se odražava na sušnost vegetacije pa su te godine vrijednosti vegetacijskih indeksa vrlo niske. S druge strane, u srpnju 2011. zabilježeno je 133 mm padalina (DZS) što je četiri puta više od mjesečnog prosjeka (DHMZ), a to bi moglo dovesti do povećanja izraženosti vegetacije sredinom kolovoza kada je napravljena snimka tog prostora.


Iz gore navedenih primjera može se zaključiti kako analize temeljene na razlici u vrijednostima NDVI indeksa uvelike ovise o klimatskim faktorima te nisu primjerene za prikazivanje direktnog ljudskog utjecaja na okoliš, poput primjerice gradnje cesta, širenja grada ili pošumljavanja (što je u ovom radu cilj), osim u slučaju kada promatrana razdoblja imaju identična klimatska obilježja. Ipak, unutar nekih razdoblja ne dolazi do ekstremne distribucije pozitivnih ili negativnih piksela pa se tako u razdoblju 1972. – 1990. mogu uočiti intenzivnije promjene na jugozapadnom dijelu (Sl. 5a), dok su u razdoblju 2000. – 2005. intenzivnije promjene na sjevernom i sjeveroistočnom dijelu promatranog prostora pa se primjerice, može uočiti izgradnja autoceste (Sl. 5c), a te su promjene vidljive i na slici 6.



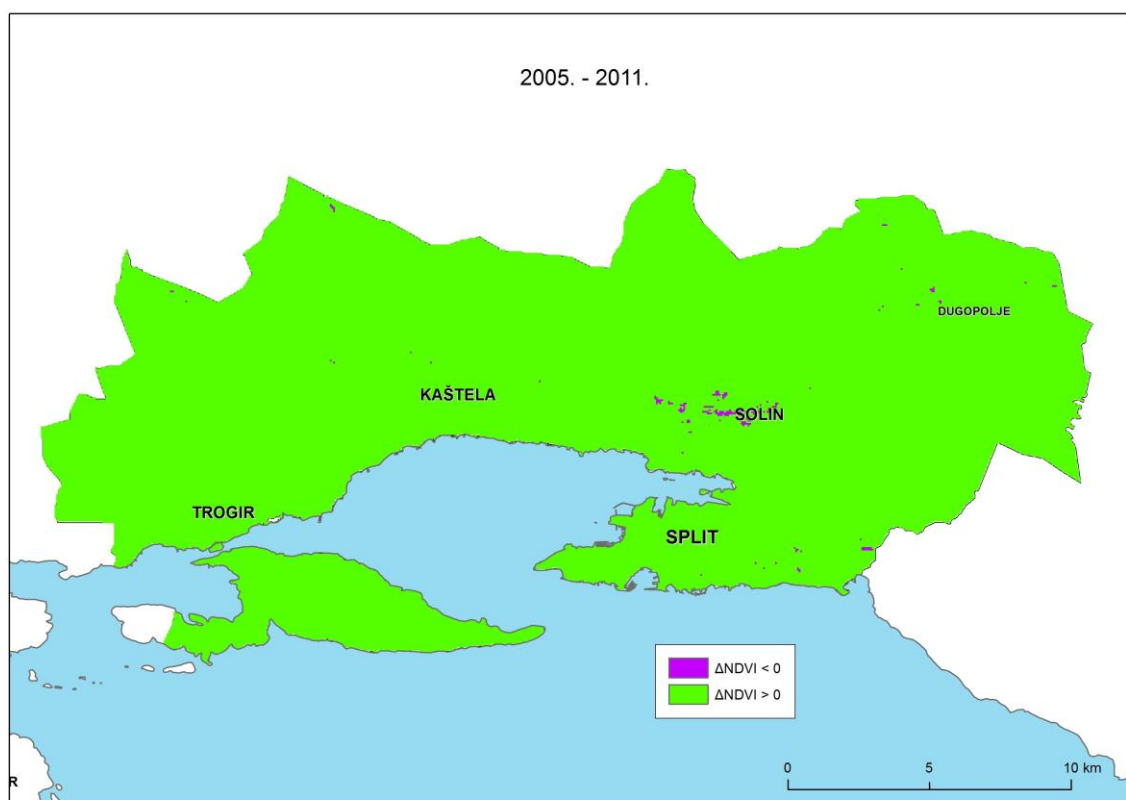
a)



b)

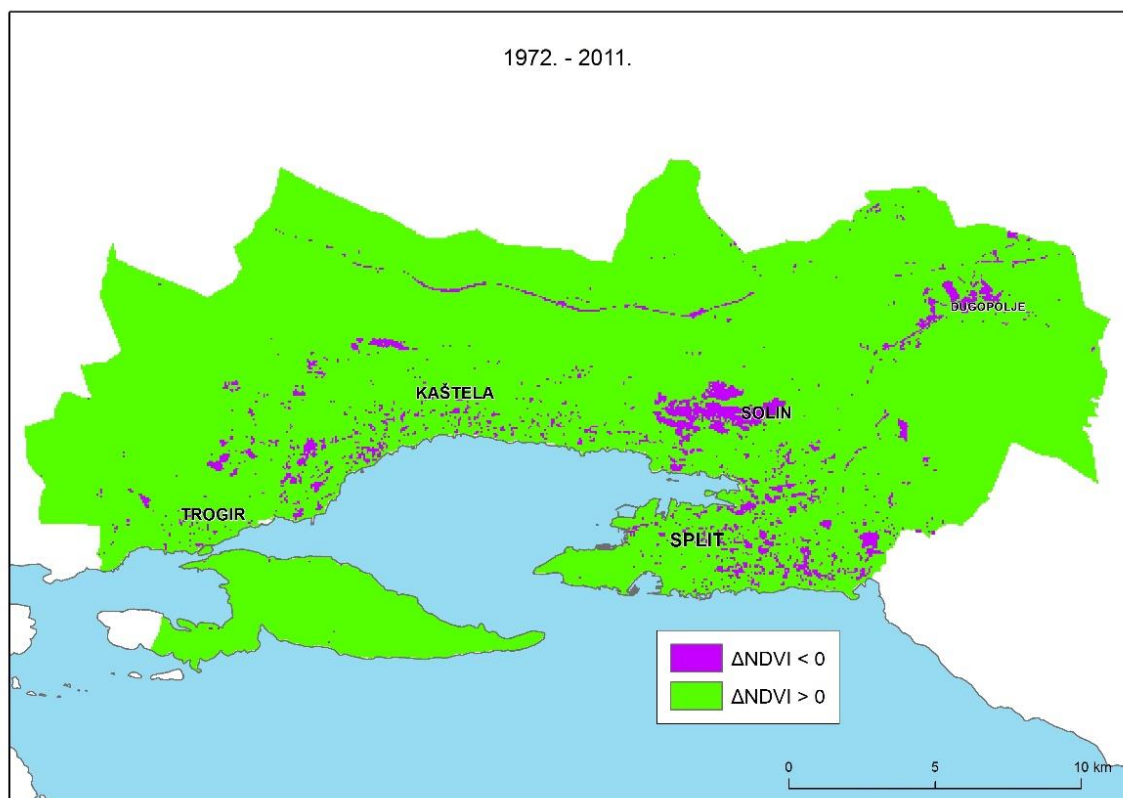


c)



d)

Sl. 5. Promjena NDVI vrijednosti u razdobljima: a) 1972. – 1990., b) 1990. – 2000., c) 2000. – 2005. i d) 2005. – 2011.



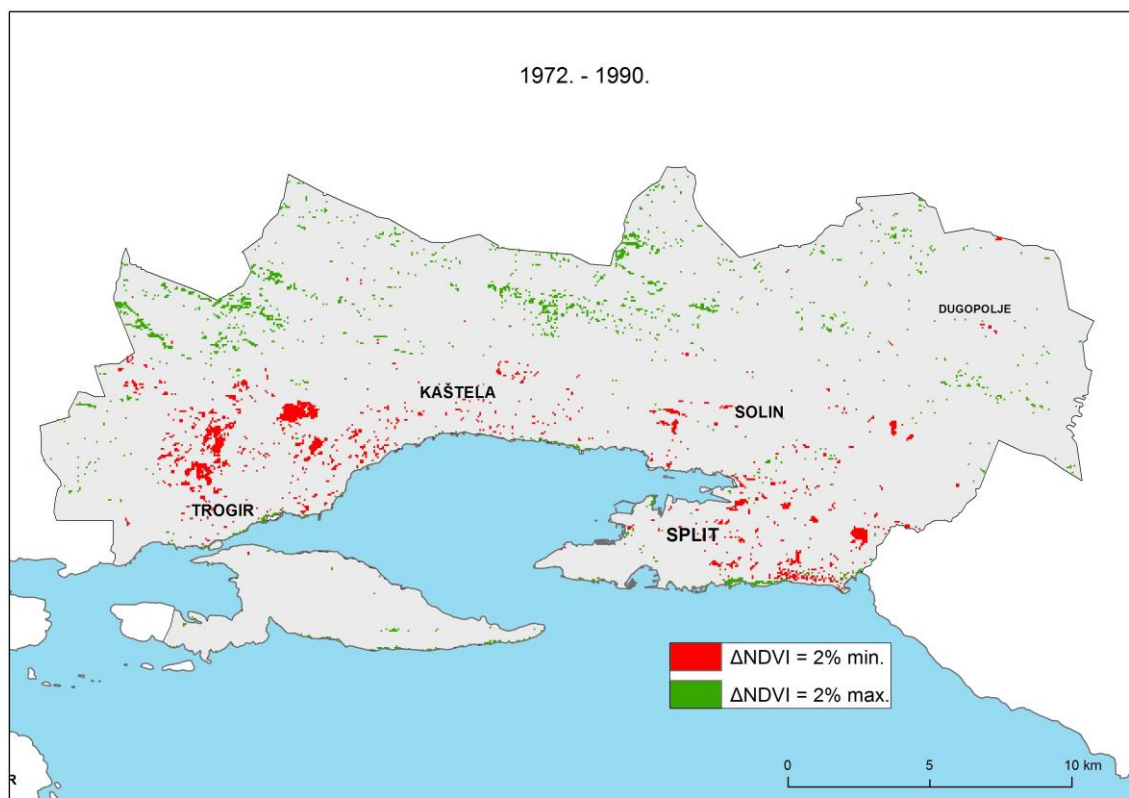
Sl. 6. Promjena NDVI vrijednosti u razdoblju 1972. – 2011.

Zbog gore navedenih razloga, u analizi su korištene relativne vrijednosti koje daju točnije podatke o transformaciji prostora. Kako bi se odredio udio promjena koji će služiti za promatranje relativnih promjena u ovom radu, određena je građevina za koju je poznato kada je izgrađena te obuhvaća veći broj piksela. Radi se o LDC terminalu u Dugopolju koji zajedno s parkiralištem zauzima prostor od oko 150 000 km² te je lako prepoznatljiv na snimci iz 2011. godine, dok je na snimci iz 2005. godine na tom području vidljiva vegetacija. Nakon nekoliko pokušaja određena je vrijednost od 2% piksela za najintenzivnije pozitivne i negativne promjene.

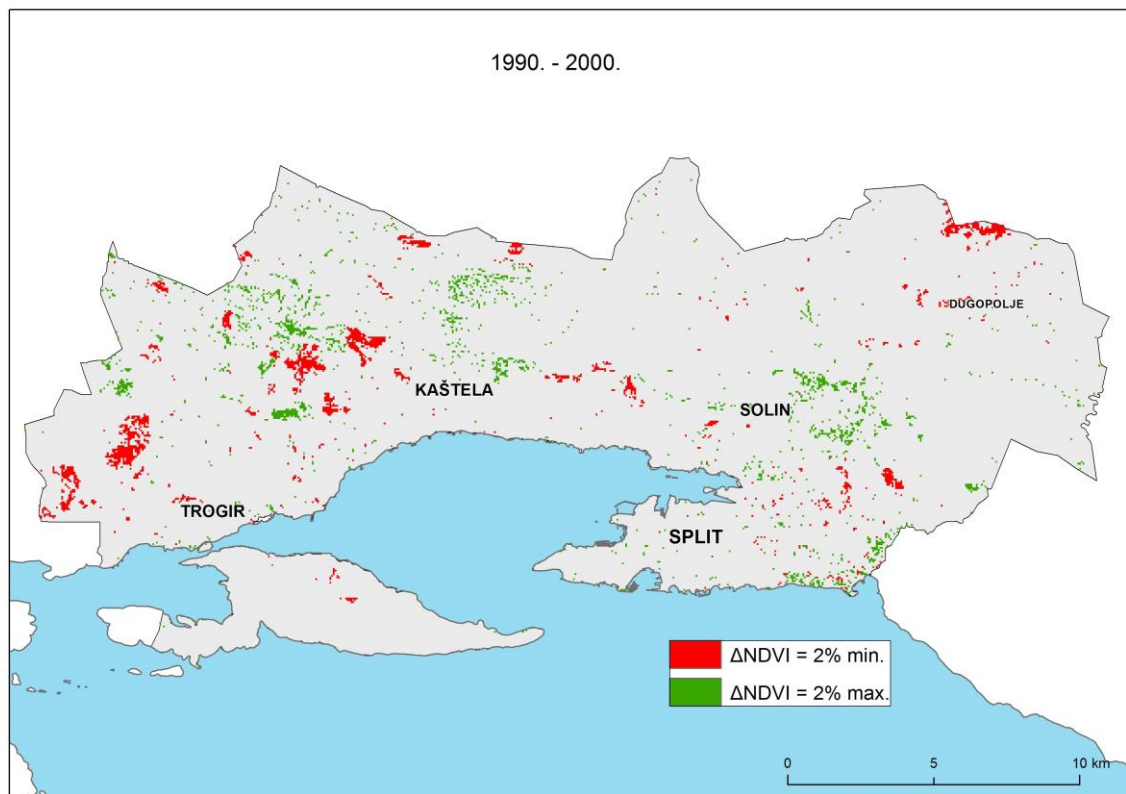
Vrijednost od 2% najnegativnijih promjena će u potpunosti obuhvatiti navedenu građevinu (označeno plavim krugom na slici 7d). Manji relativni udjeli neće biti dovoljni da u potpunosti obuhvate tu građevinu, dok će veći udjeli povećati mogućnost da su promjene uzrokovane varijacijama u vegetaciji, a taj problem je glavni razlog zašto se kreće u analizu relativnih udjela.

NDVI vrijednosti su pretvorene u cijele brojeve te je napravljena atributivna tablica pomoću koje je određeno 2040 najpozitivnijih i najnegativnijih piksela koji su zatim klasificirani u 2 razreda (Sl. 7.). Glavni nedostatak takve metode je pretpostavka kako će promjene unutar vremenskih razdoblja obuhvaćati identičan broj piksela.

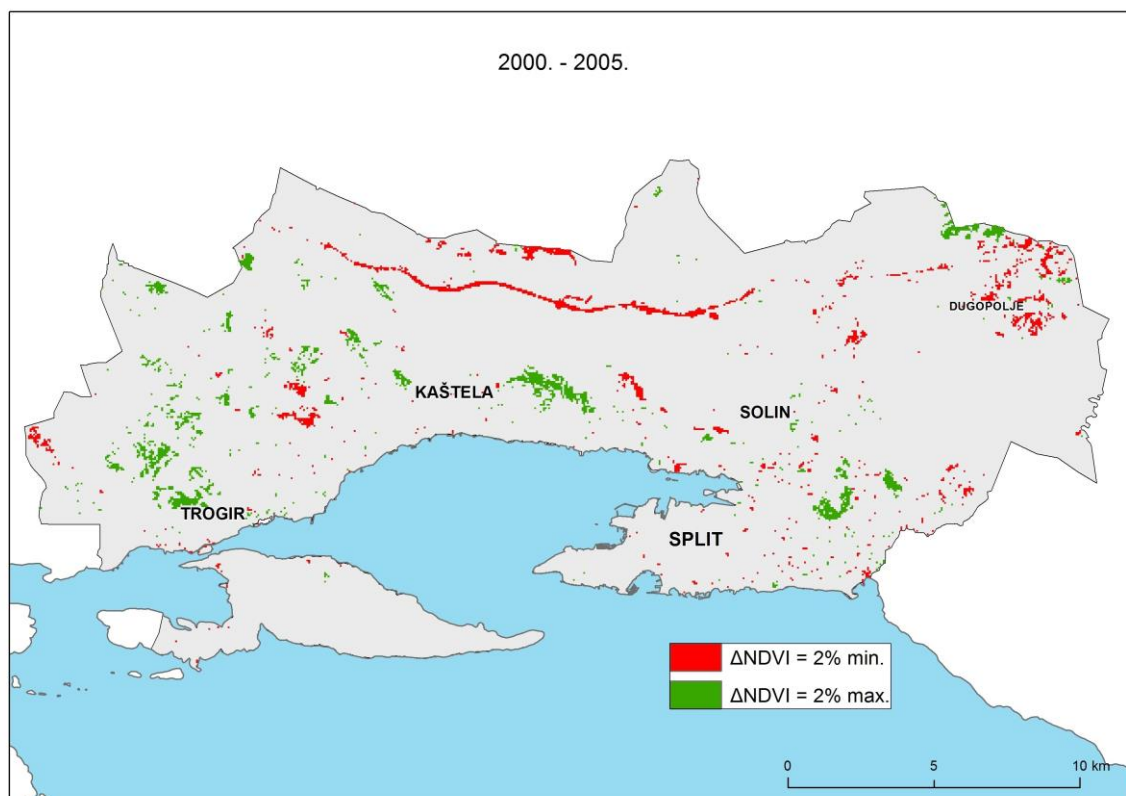
Nije moguće je odrediti stvaran intenzitet promjena unutar 18 godina jednog razdoblja ili unutar 5 godina nekog drugog razdoblja. Ako se pretpostavi kako se promjene odvijaju linearno s prolaskom vremena, tada bi se za svaki vremenski period odredio zasebni postotak udjela promjena koji bi mu bio proporcionalan. Međutim, u stvarnosti može doći do velikog broja intenzivnih promjena u kraćem vremenskom periodu, poput primjerice izgradnje autoceste A1, požara ili drugih intenzivnih promjena, dok s druge strane u dugom vremenskom periodu ne treba doći do intenzivnih promjena. Stoga je u daljnjoj analizi (Sl. 7.) obuhvat promjena u svakom vremenskom periodu kvantitativno jednak, a analiziraju se samo njihove raspodjele u prostoru.




a)



b)



c)




d)

Sl. 7a prikazuje 2% najpozitivnijih i 2% najnegativnijih promjena u razdoblju 1972. – 1990., Sl. 7b u razdoblju 1990. – 2000., Sl. 7c u razdoblju 2000. – 2005., te Sl. 7d u razdoblju 2005. – 2011.

Manji točkasti poligoni su smješteni najčešće u naseljenim područjima te predstavljaju promjenu u pokrovu uzrokovanu gradnjom cesta, kuća ili zgrada. Veći poligoni, ponajprije oni na slikama 7a, 7b i 7d nalaze se izvan naseljenih područja te predstavljaju uklanjanje vegetacije s tog područja koje može biti uzrokovano radi stvaranja, primjerice, kamenoloma ili je pak vegetacija nestala, zbog nepredviđenih okolnosti, poput primjerice požara. Osim toga, takve pojave su mogle biti uzrokovane i pojavom oblaka.

Razdoblje između 2000. i 2005. godine obilježila je gradnja autoceste A1. Valja napomenuti kako je promjena na krajnjem istočnom djelu slike (označeno crvenim u tablici 3 i smeđim krugom na slici 7d) nastala zbog pojave oblaka koji pak reflektiraju jako puno zračenja u crvenom i infracrvenom dijelu spektra, što smanjuje njihove međusobne razlike a time i NDVI. Njihove sjene pak emitiraju jako malo zračenja, što također smanjuje NDVI vrijednosti. Oblaci su bili prisutni 2005. godine, a njihov nestanak 2011. godine je doveo do velike pozitivne razlike između ta dva razdoblja. Kao što je već spomenuto, oblaci imaju određene spektralne karakteristike, a pomoću njih se mogu i diskriminirati od ostalih pojava.

Sloj na temelju kojeg su snimci izrezani od mora temeljito se na najnovijoj snimci što znači da su neki novoizgrađeni objekti, poput primjerice marine kod Kaštela 2002. godine (Marina Kaštela, 2014) također zabilježene. Međutim, s obzirom na to da more ima negativnije NDVI vrijednosti od većine kopnenih objekata, promjena je zabilježena kao povećanje vegetacijskog indeksa bez obzira na to što se radi o širenju urbanih objekata (Sl. 8). To potvrđuje činjenicu kako je NDVI mora niži od urbanog prostora pa on nije primjeren za ovakve analize, već se umjesto njega može koristiti NDWI (*Normalized difference water index*). Na slici 8. se vidi kako su najpozitivnije promjene NDVI vrijednosti u razdoblju 2000. – 2005. na području uz obalu. Razlog toga može biti izgradnja marine na tom prostoru koja će se zabilježiti kao povećanje NDVI indeksa ili se može raditi o varijacijama morske vegetacije.



Sl. 8. Područje Marina Kaštela: 2000. godine (a), 2005. godine (c) dolazi do znatne izgradnje na tom području. Zelena boja na slici b) prikazuje 20% piksela s najpozitivnijom promjenom NDVI-a u razdoblju 2000. – 2005.

Kako bi se usporedio porast i pad NDVI vrijednosti u pojedinim administrativno-teritorijalnim jedinicama, u ArcMapu je izrađen zonalni histogram. Podaci su zatim uspoređeni međusobno, te sa površinom svake administrativne jedinice u kojoj se nalaze pikseli koji su zahvaćeni najizrazitijim relativnim promjenama (Tab. 3., 4. i 5.)

Tab. 3. Broj najpozitivnijih 2% piksela u pojedinom razdoblju po naseljima

Naziv naselja	1972. - 1990.	1990. - 2000.	2000. - 2005.	2005. - 2011.
Arbanija	2	1	6	0
Blaca	54	13	4	32
Divulje	6	3	6	10
Dugopolje	99	51	154	1047
Kamen	0	25	19	5
Kaštel Gomilica	16	5	95	2
Kaštel Kambelovac	4	42	127	0
Kaštel Lukšić	25	221	6	8
Kaštel Novi	13	158	133	84
Kaštel Stari	19	11	67	28
Kaštel Sućurac	18	17	118	122
Kaštel Štafilić	13	129	29	262
Klis	46	320	26	13
Konjsko	65	27	4	40
Koprivno	72	4	53	2
Kučine	1	10	43	57
Labin	414	202	188	16
Mastrinka	1	1	0	0
Mravince	10	9	184	13
Okrug Gornji	11	19	0	1
Plano	1	5	7	22
Radošić	223	171	110	52
Seget Donji	9	8	3	6
Seget Gornji	73	96	329	0
Slatine	38	6	0	0
Solin	18	101	38	45
Split	126	118	22	38
Stobreč	24	70	10	2
Trogir	55	34	191	31
Veliki Bročanac	215	20	17	0
Vranjic	4	0	3	0
Vučevica	281	72	6	0
Žedno	1	0	0	0
Žrnovnica	11	66	40	99
Ukupno	1968	2035	2038	2037

Proučavanjem slijeda pozitivnih i negativnih promjena tijekom razdoblja utvrđeno je kako većini pozitivnih promjena u nekom razdoblju prethode negativne promjene u prošlom razdoblju na tom istom području, te se to ne događa samo kod pojave oblaka. Stoga se može zaključiti kako su pozitivne promjene uzrokovane ponajprije obnovom vegetacije na nekom području zbog, primjerice, prekida intenzivnog korištenja nekog prostora, ili oporavka od požara, a mogu biti uzrokovane prirodnom obnovom ili pak ciljanim pošumljavanjem.

Tab. 4. Broj najnegativnijih 2% piksela u pojedinom razdoblju po naseljima

Naziv naselja	1972. - 1990.	1990. - 2000.	2000. - 2005.	2005. - 2011.
Arbanija	5	13	4	0
Blaca	8	14	122	207
Divulje	27	7	1	4
Dugopolje	18	210	436	123
Kamen	91	10	10	19
Kaštel Gomilica	13	25	2	1
Kaštel Kambelovac	40	1	0	10
Kaštel Lukšić	43	1	113	52
Kaštel Novi	67	333	35	31
Kaštel Stari	21	126	11	24
Kaštel Sućurac	83	86	108	96
Kaštel Štafilić	377	56	132	21
Klis	75	22	86	36
Konjsko	3	14	80	9
Koprivno	0	51	31	308
Kučine	0	46	18	1
Labin	84	101	28	41
Mastrinka	0	0	0	0
Mravince	19	65	16	1
Okrug Gornji	2	0	8	1
Plano	72	27	8	6
Radošić	5	106	146	60
Seget Donji	10	9	9	1
Seget Gornji	174	475	68	19
Slatine	4	14	0	9
Solin	79	39	55	534
Split	308	44	55	47
Stobreč	55	27	20	5
Trogir	310	31	25	19
Veliki Bročanac	0	5	23	6
Vranjic	11	0	2	6
Vučevica	0	47	308	312
Žedno	0	0	0	4
Žrnovnica	35	32	76	24
Ukupno	2039	2037	2036	2037

Vidljivo je kako postoje znatne varijacije između pojedinih razdoblja na istom području. Većina takvih izrazitih promjena povezana je s većim poligonima koji karakteriziraju izgradnju većih objekata ili druge značajne antropogene transformacije prostora poput izgradnje kamenoloma, staklenika ili velikih poljoprivrednih površina. Kako bi se utvrdilo koliko proces suburbanizacije utječe na promjene NDVI vrijednosti, dobivene vrijednosti će se usporediti s promjenom broja stanovnika na tim prostorima.

Tab. 5. Usporedba udjela negativne promjene NDVI-a s relativnom i apsolutnom promjenom broja stanovnika po naseljima

Naziv naselja	Udio negativnih vrijednosti NDVI-a (Sl. 6., 1972. - 2011.) u površini naselja (%)	Promjena broja stanovnika	Indeks promjene broja stanovnika
Solin	24,16	11075	221
Kamen	19,03	1397	476
Plano	14,32	343	263
Stobreč	13,27	2078	331
Divulje	12,36	-10	72
Split	12,25	43365	135
Kaštel Sućurac	12,24	1509	128
Vranjic	11,00	-375	75
Kaštel Štafilić	10,29	1644	218
Kaštel Stari	8,27	4153	243
Kaštel Gomilica	6,83	2566	211
Kaštel Novi	5,80	4116	279
Mravince	5,45	683	172
Blaca	5,10	-2	50
Kaštel Kambelovac	4,71	2691	215
Dugopolje	4,38	328	112
Kaštel Lukšić	4,12	3183	242
Trogir	3,32	4746	177
Klis	3,03	825	138
Žrnovnica	2,56	1437	181
Seget Donji	2,43	1404	210
Kučine	1,93	561	236
Vučevica	1,78	-179	24
Koprivno	1,69	-54	83
Konjsko	1,03	-40	88
Arbanija	0,92	151	168
Seget Gornji	0,62	-474	22
Radošić	0,55	-458	28
Labin	0,48	-400	20
Veliki Broćanac	0,45	-124	56
Okrug Gornji	0,20	2172	339
Žedno	0,20	-59	69
Slatine	0,03	339	144
Mastrinka	0,00	947	0

Izvor: DZSb (broj stanovnika)

Analizom tablice 5. može se uvidjeti određena povezanost između negativnih NDVI vrijednosti i pozitivne promjene broja stanovnika, ponajprije kod Solina, Kaštela i naselja u predgrađu Splita. Ipak, broj iznimaka (to su ponajprije manja naselja u unutrašnjosti) je prevelik da bi se moglo govoriti o pozitivnoj korelaciji između te dvije pojave. Zbog toga se može zaključiti kako ostali čimbenici koji uzrokuju smanjenje NDVI vrijednosti imaju vrlo važnu ulogu na ovom prostoru.


Ti čimbenici mogu se podijeliti u dvije skupine: Prvi skupinu čine novi antropogeni objekti u prostoru koji nemaju stambenu namjenu (autoceste, skladišta itd.). Kod stambenih objekata je potrebno pak istaknuti izgradnju, pa će tako veća kuća i neboder imati slične NDVI vrijednosti, a veliku razliku u broju ljudi koji tamo mogu živjeti. Ipak, ta činjenica u ovom slučaju ne bi trebala predstavljati znatan problem jer vizualnim promatranjem satelitskih snimaka utvrđeno kako većina naselja izuzev Splita ima minimalan broj nebodera. Drugu skupinu čine prirodne pojave poput oblaka ili požara koji mogu dovesti do krive interpretacije podataka, a valja istaknuti i varijabilnost vegetacije između godina zbog količine padalina.

S obzirom na to da se radi o području krša te o prostoru mediteranske makije, s malo šuma i velikim udjelom ogoljelih kamenih površina, negativni vegetacijski indeksi osim urbanih područja obuhvaćaju i područje golog krša što otežava analizu suburbanizacije. Kako bi se prostor krša diferencirao od urbanih površina korišten je NDRI (*Normalized difference rock index*) koji se temelji na odnosu kratkovalnog infracrvenog zračenja i crvenog zračenja (Huang i Cai, 2008). Područja krša zbog svojih specifičnih karakteristika imat će povećanu razliku između navedena dva tipa elektromagnetskog zračenja. U slučaju TM i ETM+ senzora dobiva se kao: $(\text{Kanal } 5 - \text{kanal } 3) / (\text{kanal } 5 + \text{kanal } 3)$. Uspješnost korištenja 5. spektralnog kanala za raspoznavanje ogoljelog krša od urbanih područja potvrđuju i vlastite analize sa slika 3. i 4.


Razlike NDVI vrijednosti sa slike 9. (tamnija boja ukazuje na negativne, svjetlija na pozitivne promjene) jasno ukazuju na problematiku raspoznavanja krša od urbanih područja. Za razliku od toga, na slici 10. se vidi kako su razlike NDRI vrijednosti kod nenaseljenih krških područja (primjerice između autoceste A1 i Kaštela) manje nego na slici 10. što potvrđuje uspješnost te metode ako se želi ignorirati promjena u pokrivenosti vegetacije kod nenaseljenih područja.

Kao primjer takve metode koristi se negativna promjena NDVI-a sa slike 7d kod koje će se izbaciti one promjene koje imaju veće vrijednosti od aritmetičke sredine NDRI vrijednosti iz 2011. godine (Sl. 11.). Promatranjem ortofoto snimaka ustanovljeno je kako se gotovo sve takve promjene (označene plavom bojom) nalaze na područjima gdje nisu izgrađeni nikakvi objekti pa je takva metoda bolja za promatranje procesa suburbanizacije. Ti podaci se tada mogu usporediti s podacima u tablici 4. pa se može primjerice ustanoviti, kako negativne promjene NDVI vrijednosti u općini Vučevica (označeno smeđim krugom

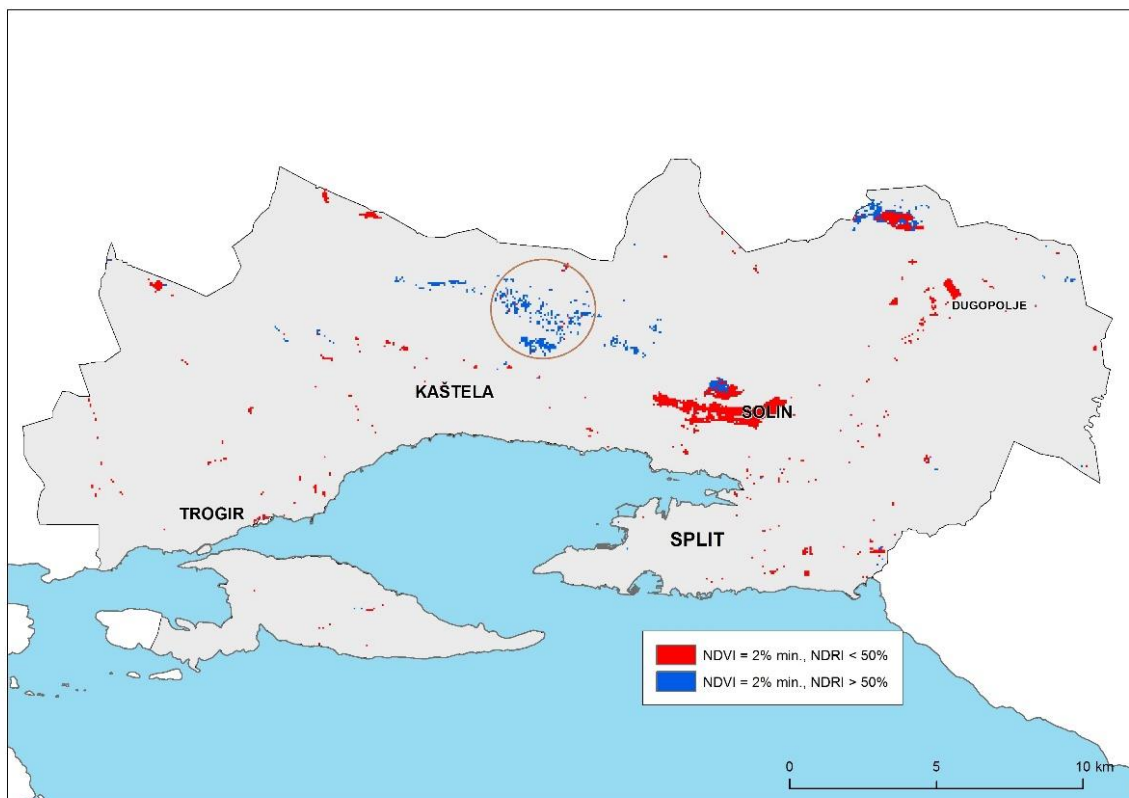
na slici 11.) u razdoblju 2005.- 2011. nisu uzrokovane gradnjom objekata, već su posljedica promjena u intenzitetu vegetacije.



Sl. 9. Razlika NDVI vrijednosti Kaštelanskog zaljeva između 2011. i 2005. godine



Sl. 10. Razlika NDRI vrijednosti Kaštelanskog zaljeva između 2011. i 2005. godine



Sl. 11. Primjer relativnih promjena NDVI vrijednosti s aritmetičkom sredinom NDRI vrijednosti iz 2011. godine kao dodatnim parametrom. Razdoblje je 2005. – 2011.

Kako bi se što bolje interpretirale promjene u prostoru, važno je razlikovati podtipove negativnih promjena. Prvu skupinu čine promjene koje nisu posljedica izgradnje objekata, istaknute na slici 11. Drugu skupinu čine objekti koji su posljedica antropogenih utjecaja, ali ne uključuju zgrade već objekte poput autocesta i kamenoloma, a karakterizirane su većim poligonima. Treću skupinu čine objekti koji bi trebali biti uzrokovani izgradnjom kuća zgrada, ili drugih manjih objekata, a karakterizirani su sitnim točkicama na području Splita, Solina i Kaštela, vidljivim na slici 7.

Pretpostavka kako su negativne promjene NDVI vrijednosti direktna posljedica povećanja broja stanovnika i procesa suburbanizacije se ipak ne može potvrditi. Oni su samo jedan od čimbenika koji utječu na smanjenje NDVI-a, no s obzirom na to kako se ostali čimbenici poput krčenja vegetacije ili pak pojave suša i požara ne mogu kvantificirati jer su detaljni povijesni podaci o njima teško dostupni, može se samo zaključiti kako oni imaju znatan utjecaj na ovom prostoru.

6. ZALJUČAK

Za razliku od običnih slika koje su podložne subjektivnoj interpretaciji, iza svake Landsat snimke kriju se kvantitativni podaci o vrijednosti piksela. Te vrijednosti proizlaze iz elektromagnetskog zračenja specifičnih valnih duljina koje čine određeni spektralni kanal. Kombinacijom različitih spektralnih kanala može se dobiti mnoštvo preciznih kvantitativnih podataka na temelju kojih će se prostori klasificirati u specifične razrede. Kako bi se snimka mogla što bolje interpretirati, neophodno je poznavanje prostora koji se proučava. U ovom radu proučava se prostor oko Kaštelanskog zaljeva čija interpretacija zahtjeva specifične metode.

Utvrđeno je kako zbog vegetacijskih i reljefnih karakteristika ovog prostora nije moguće uvijek koristiti razlike vrijednosti NDVI-a ako se žele utvrditi promjene u prostoru. Tako su u ovom slučaju za pojedinačna razdoblja bolje rezultate dale relativne vrijednosti promjena NDVI-a, koje ne ukazuju na intenzitet promjena već ponajprije na njihovu raspodjelu u prostoru. Za tumačenje zabilježenih promjena može se koristiti veličina pojedinih poligona, zatim promatranje sukcesije pozitivnih promjena nakon negativnih te korištenje 5. spektralnog kanala koji znatno pomaže u razlikovanju krša od urbanih područja. Konačno, NDVI indeks se ne može koristiti kao primarni ili jedini pokazatelj određenih promjena u prostoru, poput primjerice suburbanizacije, jer na njegove promjene ne utječe samo čovjek direktnom promjenom okoliša, već i brojni prirodni čimbenici.

Ovom analizom utvrđeno je mnogo prepoznatljivih objekta i pojava u prostoru. Najveće zabilježene promjene koje su posljedica direktne ljudske intervencije posljedica su izgradnje autoceste A1, a osim nje uočeni su brojni novoizgrađeni objekti, nestanak i pojava vegetacije zbog prenamjene zemljišta te pojave poput požara i oblaka. Prostor Kaštelanskog zaljeva je tijekom promatranih 40 godina doživio brojne transformacije njegovih dijelova koje su bile uzrokovane različitim čimbenicima što doprinosi specifičnosti tog prostora.

Landsat snimci mogu biti korisni za mnoga istraživanja u geografiji. Njihova glavna prednost je besplatna dostupnost preko interneta te dugi kontinuitet rada od 45 godina. U razdoblju velikih globalnih promjena poput naglog porasta svjetske populacije ili klimatskih promjena, Landsat snimci su izrazito važan dokaz tih promjena te će oni dobivati na važnosti prolaskom vremena. Ti snimci postaju dio ljudske povijesti te je zbog toga izrazito važno nastaviti Landsat program u budućnosti.

LITERATURA

1. Campbell, J. B., Wayne, R. H., 2011: *Introduction to Remote Sensing*, The Guilford press, New York.
2. Custer, J. F., Eveleigh, T., Klemas, V., Wells, I., 1986: Application of LANDSAT Data and Synoptic Remote Sensing to Predictive Models of Prehistoric Archeological Sites: An Example from Delaware Coastal Plain, *American Antiquity*, vol. 51., No. 3. (Jul., 1986)., pp. 572-588.
3. Dozier, J., 1989: Spectral Signature of Alpine Snow Cover from the Landsat Thematic Mapper, *Remote Sensing of Environment*. 28:9-22.
4. Huang, Q., Cai, Y., 2008: Mapping Karst Rock in Southwest China, *Mountain Research and Development*, 29(1):14-20., International Mountain Society
5. Kauth, R. J., Thomas, G. S., 1976: The Tasselled Cap - A Graphic Description of the Spectral-Temporal Development of Agricultural Crops as Seen by LANDSAT". *LARS Symposia*. Paper 159.
6. Lillesand, T. M., Kiefer, R. W., Chipman, J. W., 2004: *Remote sensing and image interpretation*, Wiley US.
7. Masek, J. G., Lindsay, F. E., Goward, S. N., 2000: Dynamics of urban growth in the Washington DC metropolitan area, 1973–1996, *Landsat observations, Int. J. Remote sensing*, 2000, vol. 21, no. 18, 3473–3486.
8. Richards, J. A., Jia, X., 2006: *Remote Sensing Digital Image Analysis*, Springer, Heidelberg.
9. Šimić Milas, A., Rupasinghe, P., Balenović, I., Grosevsk, P., 2015: Assessment of Forest Damage in Croatia using Landsat-8 OLI Images, *South-east Eur for* 6 (2): 159-169. DOI: <http://dx.doi.org/10.15177/seefor.15-14>.
10. Tucker, C. J., 1978: *Red and Photographic Infrared Linear Combinations for Monitoring Vegetation*, NASA/Goddard Space Flight Center Greenbelt, Maryland.
11. Wulder, M. A., Masek, J. G., Cohen, W.B., Loveland T.R., Woodcock, C.E., 2012: Opening the archive: How free data has enabled the science and monitoring promise of Landsat, *Remote Sensing of Environment* 122 (2012) 2-10, DOI: 10.1016/j.rse.2012.01.010.

12. Yuan, F., Sawaya, K. E., Loeffelholz, B. C., Bauer, M. E., 2005: Land cover classification and change analysis of the Twin Cities (Minnesota) Metropolitan Area by multitemporal Landsat remote sensing, *Remote Sensing of Environment* 98 (2005) 317 – 328, DOI: 10.1016/j.rse.2005.08.006.

IZVORI PODATAKA

1. Available Data Products, United States Geological Survey (USGSc),
<https://landsat.usgs.gov/available-data-products> (15. 8. 2017.)
2. GloVis, United States Geological Survey (GloVis): <https://glovis.usgs.gov/>,
(25.6.2017.)
3. Landsat 9, National Aeronautics and Space Administration (NASAc),
<https://landsat.gsfc.nasa.gov/landsat-9/> (15. 8. 2017.)
4. Landsat Acquisition, United States Geological Survey (USGSd),
<https://landsat.usgs.gov/acquisition> (11.8. 2017.)
5. Landsat Band Designations, United States Geological Survey (USGSb),
<https://landsat.usgs.gov/what-are-band-designations-landsat-satellites> (3. 7. 2017.)
6. Landsat Orbit Paths, United States Geological Survey (USGSe),
<https://landsat.usgs.gov/what-are-orbit-paths-landsat-satellites> (17. 8. 2017.)
7. Landsat Timeline, United States Geological Survey (USGSa),
<https://landsat.usgs.gov/landsat-missions-timeline> (3. 7. 2017.)
8. Marina Kaštela, <http://www.marina-kastela.hr/marina/>, (25. 6. 2017.)
9. MODIS, National Aeronautics and Space Administration (NASAb),
<https://modis.gsfc.nasa.gov/about/specifications.php> (11 .8. 2017.)
10. Narodne Novine (NN 24/10),
http://narodne-novine.nn.hr/clanci/sluzbeni/2010_02_24_574.html (23. 6. 2017.)
11. Popis stanovništva 2011., Državni zavod za statistiku (DZSb),
<https://www.dzs.hr/hrv/censuses/census2011/censuslogo.htm> (24. 8. 2017.)
12. Sentinel Resolutions, European Space Agency (ESA),
<https://earth.esa.int/web/sentinel/user-guides/sentinel-2-msi/resolutions/spatial>
(15.8. 2017.)
13. Srednje mjesečne vrijednosti - Split, Državni hidrometeorološki zavod (DHMZ),
<http://klima.hr/klima.php?id=k1¶m=srednjak&Grad=split> marjan (23. 6.
2017.)
14. *Statistički ljetopis Republike Hrvatske 2012.*, Državni zavod za statistiku (DZS),
Zagreb, 2012. https://www.dzs.hr/Hrv_Eng/ljetopis/2012/sljh2012.pdf (23. 6.
2017.)

15. The Atmosphere, National Aeronautics and Space Administration (NASA),
<https://www.grc.nasa.gov/www/k-12/airplane/atmosphere.html> (15. 8. 2017.)
16. WordldView 4, DigitalGlobe, <http://worldview4.digitalglobe.com/#/main> (3.7. 2017.)